

# Segmentation d'images scanner X du foie par Max-Flow/Min-Cut

Kristel TORRES<sup>1,2</sup>, Thiên-Ly PHAM<sup>1,2</sup>, Simon ESNEAULT<sup>1,2</sup>, Jean-Claude NUNES<sup>1,2</sup>, Eric DELABROUSSE<sup>3</sup>, Jean-Louis DILLENSEGER<sup>1,2</sup>

<sup>1</sup>INSERM, U 642, Rennes, F-35000 France

<sup>2</sup>Université de Rennes 1, LTSI, F-35000, France

LTSI, Campus de Beaulieu, Université de Rennes 1, 35042 Rennes Cedex, France

<sup>3</sup>INSERM, U 556 Lyon, F-69424, France

[simon.esneault@univ-rennes1.fr](mailto:simon.esneault@univ-rennes1.fr), [jean-claude.nunes@univ-rennes1.fr](mailto:jean-claude.nunes@univ-rennes1.fr)  
[eric.delabrousse@tele2.f](mailto:eric.delabrousse@tele2.f), [jean-louis.dillenseger@univ-rennes1.fr](mailto:jean-louis.dillenseger@univ-rennes1.fr)

**Résumé** – Dans le contexte d'une application médicale spécifique, le traitement mini-invasif des cancers primitifs du foie par ultrasons à haute intensités, notre étude porte sur une méthode de segmentation 3D semi-automatique rapide qui permet d'isoler le foie et les différents réseaux vasculaires hépatiques à partir de volumes acquis en scanner X. Cette méthode est caractérisée par une description du volume sous la forme d'un graphe où les poids des liens entre noeuds décrivent soit des degrés de similarité entre voxels de la même classe (approche région), soit des degrés de discontinuité d'un voxel par rapport à un voisin (approche contours). Ces différents poids sont définis après une première phase d'apprentissage interactive. L'algorithme de Max-Flow/Min-Cut est ensuite utilisé pour partitionner le volume en deux sous-ensembles représentatifs des classes.

**Abstract** – Within a specific medical application, the primary liver cancer curative treatment by a percutaneous high intensity ultrasound surgery, our study was designed to propose a fast 3D semi-automatic segmentation method of the liver, the tumor and the hepatic vascular networks. This method is characterized by a graph description of contrast medium injected CT volume where the links between the nodes describe either the degrees of similarity between voxels of the same class (region based approach) or the class changes between two neighboring voxels (boundary based approaches). The various weights describing these two properties are defined after a first interactive training phase. A Max-Flow/Min-Cut graph cut algorithm allowed partitioning the volume in two representative subsets of the segmented classes.

## 1 Introduction

Le carcinome hépatocellulaire ou cancer primitif du foie est une tumeur des cellules du parenchyme du foie dont l'incidence est grandissante en occident et c'est le cancer le plus commun dans certaines parties du monde, avec plus d'un million de nouveaux cas diagnostiqués par an [1]. Si elle est appréhendée suffisamment tôt, cette lésion, souvent unique, peut être traitée de manière curative en chirurgie par l'ablation partielle du foie [2]. Les patients dont la tumeur est localisée mais non opérable du fait de sa localisation dans le foie ou à cause de considérations médicales (cirrhose du foie) sont alors candidats à une chirurgie percutanée (injection d'éthanol, radiofréquence) [3]. Une nouvelle thérapie percutanée, la chirurgie par ultrasons, est maintenant proposée avec un applicateur interstitiel [4]. Elle permet un meilleur contrôle en puissance et en direction que les autres techniques. Mais comme toutes chirurgies mini-invasives guidées par ultrasons cette procédure implique la définition d'un planning préopératoire précis ainsi que le suivi et le contrôle de l'action thérapeutique.

La sonde thérapeutique ultrasonore est constituée d'un petit transducteur ultrasonore plan mono-élément (3-4 mm) incorporé dans un applicateur cylindrique intersti-

tiel. Le processus thérapeutique s'effectue selon les étapes suivantes : 1) l'applicateur interstitiel est guidé sous imagerie échographique à l'intérieur ou à la périphérie de la tumeur hépatique ; 2) les paramètres du planning thérapeutique (temps et puissance du tir par ultrasons de haute intensité, angle de rotation du transducteur après chaque tir et rotation totale du transducteur) sont appliqués pour échauffer et détruire la tumeur. La taille de la nécrose est directement liée au temps du traitement et à la température atteinte lors de l'échauffement. Or cet échauffement peut être perturbé localement par la présence de vaisseaux sanguins agissant comme des refroidisseurs. Il est donc important de définir au mieux le cadre anatomique et donc de localiser la tumeur par rapport à la vascularisation hépatique.

En routine clinique le planning préopératoire est établi sur la base d'images du volume du patient acquises en scanner X à différents stades d'injection de produit de contraste. L'imagerie du stade portal-veineux offre souvent une image suffisamment contrastée de la tumeur et du réseau vasculaire. L'objectif de notre travail est de proposer une méthode de segmentation rapide qui permet d'isoler le foie, les différents réseaux vasculaires hépatiques et les tumeurs cibles.

## 2 Segmentation

Nous allons considérer le problème de la segmentation comme la séparation d'une image ou d'un volume en deux classes "objet" et "fond". La méthode que nous allons présenter fait partie de la classe des outils de segmentation semi-automatique qui associent de manière interactive certains des voxels du volume à l'une de ces deux classes. Cette première association sert ensuite de base d'apprentissage pour la segmentation finale du volume.

En vision par ordinateur, de nombreux problèmes peuvent s'exprimer par une minimisation d'énergie. Dans cette classe méthodologique, Greig et al. [5] puis Boykov et al. [6] ont proposé une méthode de minimisation d'énergie basée sur le partitionnement d'un graphe en deux sous-graphes par coupe de capacité minimale (Max-Flow/Min-Cut graph cut).

Cet algorithme de partitionnement de graphe peut parfaitement s'adapter à notre problématique de classification binaire du volume. De surcroît, la transcription de notre problème de segmentation sous forme de minimisation d'énergie permet de coder différentes caractéristiques de notre volume : l'apprentissage de la classification, le degré de similarité entre voxels de la même classe (approche région), la rupture entre classes (approche contour), etc.

Notre problème de segmentation est décrit sous la forme d'un graphe de flux directionnel. Ce graphe est constitué de deux nœuds particuliers appelés "nœuds terminaux", représentant respectivement la classe "objet" et la classe "fond", et de nœuds intermédiaires représentant chacun un des voxels du volume 3D. Ces nœuds sont reliés entre eux par des liens pondérés et orientés. La topologie de ces liens et les coûts initiaux qui leurs sont assignés sont représentatifs de la fonction d'énergie à minimiser.

Dans notre cas, nous avons décidé de transcrire notre problème sous la forme de la minimisation d'une fonction d'énergie constituée de deux termes :  $E_T = \lambda \cdot E_{\text{classif}} + (1 - \lambda) \cdot E_{\text{continuite}}$  avec  $E_{\text{classif}}$ , une énergie codant la probabilité qu'un voxel appartienne à la classe "objet" ou à la classe "fond" et  $E_{\text{continuite}}$ , une énergie codant le degré de similarité ou de discontinuité entre deux voxels voisins. Le coefficient  $\lambda$  contrôle la pondération entre ces deux types d'énergie.

Le graphe est construit comme ceci :

- La base topologique de  $E_{\text{classif}}$  est la suivante : chaque nœud représentatif d'un voxel est connecté par deux liens aux deux nœuds terminaux. Les liens ainsi créés portent un poids représentatif de la probabilité d'appartenance du voxel à la classe "objet" ( $w_{cl\_obj}$ ) et à la classe "fond" ( $w_{cl\_fond}$ ). Ces probabilités seront déterminées lors de la phase d'apprentissage.
- $E_{\text{continuite}}$  impose un codage du degré de similarité entre voisins. Chaque nœud représentatif d'un voxel sera connecté à ses voisins (en 6-connectivité ou 26-connectivité) par des liens pondérés par une fonction pénalisant la dissemblance ( $w_{cont}$ ).

L'algorithme de Max-Flow/Min-Cut [7] est appliqué sur ce graphe afin de le partager en deux sous-ensembles : les nœuds liés au nœud terminal "objet" et ceux liés au nœud terminal "fond", segmentant ainsi tout le volume.

## 3 Mise en oeuvre

### 3.1 Phase d'apprentissage

L'exploration visuelle d'un volume d'images médicales à l'aide des 3 plans sagittal, axial et frontal est classiquement utilisée en routine clinique. À partir de ces trois plans, et à l'aide de la souris, l'utilisateur sélectionne interactivement des voxels  $v_o$  qu'il considère appartenir à la classe "objet", et d'autres voxels  $v_f$ , qu'il considère appartenir à la classe "fond".  $v_o$  et  $v_f$  ont un double rôle : ils servent d'une part de points germes à la segmentation et, d'autre part, la distribution de leurs valeurs (histogrammes) sert de base d'apprentissage pour l'attribution des poids initiaux de  $E_{\text{classif}}$  (cf. paragraphe 3.2).

### 3.2 Assignment des poids initiaux intervenant dans le calcul de $E_{\text{classif}}$

Prenons le cas des liens couplant un nœud représentatif d'un voxel  $v$  de valeur  $I$  au nœud terminal "objet", trois cas de figures sont alors à envisager en fonction de l'appartenance ou non du voxel aux deux classes de points germes. Si  $v$  est un point germe, un poids prédéfini  $w_{cl\_obj}$  sera attribué au lien. Si  $v$  n'est pas un point germe,  $w_{cl\_obj}$  sera représentatif de la probabilité d'appartenance du voxel à la classe "objet"  $W_{objet}(I)$ .

$$w_{cl\_obj} = \begin{cases} \infty \text{ ou valeur seuil } K & \text{si } v \in v_o \\ 0 & \text{si } v \in v_f \\ \lambda \cdot W_{objet}(I) & \text{dans les autres cas} \end{cases} \quad (1)$$

De même, pour les poids  $w_{cl\_fond}$  des liens couplant un nœud représentatif d'un voxel  $v$  de valeur  $I$  au nœud terminal "fond".

$$w_{cl\_fond} = \begin{cases} 0 & \text{si } v \in v_o \\ \infty \text{ ou valeur seuil } K & \text{si } v \in v_f \\ \lambda \cdot W_{fond}(I) & \text{dans les autres cas} \end{cases} \quad (2)$$

Par contre, et contrairement au schéma proposé par Boykov et al. [7, 8], nous allons attribuer directement à  $W_{objet}(I)$  et  $W_{fond}(I)$  la probabilité que  $v$  appartienne à ces deux classes :

$$W_{objet}(I) = \Pr(I // \text{"objet"}) \quad (3)$$

$$W_{fond}(I) = \Pr(I // \text{"fond"}) \quad (4)$$

Ces deux distributions de probabilité  $\Pr(I // \text{"objet"})$  et  $\Pr(I // \text{"fond"})$  peuvent être établies a priori ou, et c'est notre cas, être déduites des histogrammes de  $v_o$  et  $v_f$ . Plus précisément, nous proposons plusieurs possibilités de déduire une distribution de probabilité à partir des histogrammes :

- L'utilisation directe des histogrammes après normalisation de leurs aires (ou intégrales). Ces histogrammes peuvent être lissés ou non avant normalisation.
- La modélisation des histogrammes par une mixture de gaussiennes. L'utilisateur définit a priori le nombre de

gaussiennes qui seront ajustées à l'histogramme par un algorithme EM [9].

### 3.3 Assignment des poids initiaux intervenant dans le calcul de $E_{continue}$

Le poids du lien entre deux nœuds voisins doit refléter le degré de similarité entre voxels. Le gradient de niveaux de gris sert communément de marqueur de discontinuité. Boykov et al. suggèrent d'utiliser la fonction ad hoc suivante pour établir le poids d'un lien entre un voxel  $v_1$  de valeur  $I_1$  au voxel voisin  $v_2$  de valeur  $I_2$  :  $w_{cont} \propto \frac{\exp(-(I_1-I_2)^2/2\sigma^2)}{\text{dist}(v_1,v_2)}$  où  $\text{dist}(v_1,v_2)$  est la distance euclidienne entre les deux voxels et  $\sigma$  l'écart type du bruit de mesure [7]. Pour notre part nous avons pondéré cette fonction par le rapport de proportionnalité suivant :

$$w_{cont} = (1 - \lambda) \cdot A \cdot \frac{\exp(-(I_1-I_2)^2/2\sigma^2)}{\text{dist}(v_1,v_2)} \quad (5)$$

où  $A$  est une constante de normalisation permettant de préserver une influence égale entre les poids initiaux de  $E_{classif}$  et de  $E_{continue}$ .  $\text{dist}(v_1,v_2)$  permet de traiter les volumes anisotropes.

## 4 Résultats

Cet algorithme a été testé sur des volumes scanner X abdominaux acquis à 4 différents stades d'injection de produit de contraste. Chaque volume est constitué d'environ 120 coupes de 512x512 pixels avec une résolution de 0,77 mm par pixel, et une épaisseur de coupe de 2 mm. Les volumes ont été interpolés afin de les rendre isotropes.

Les résultats présentés dans ce papier ont été obtenus à partir du volume correspondant à la phase parenchymateuse, mais ils peuvent être généralisés aux autres volumes. Dans un premier temps, une région d'intérêt parallélépipédique est définie interactivement sur deux coupes perpendiculaires afin de réduire la taille du graphe. La figure 1 montre les points germes sélectionnés interactivement pendant la phase d'apprentissage (en rouge -respectivement en vert- les points attribués à l'objet -respectivement au fond-)




FIG. 1 – Points germes sélectionnés dans le plan axial (à gauche) et coronal (à droite). En rouge les points attribués à l'objet, et en vert les points attribués au fond.

$\Pr(I/\text{"objet"})$  est définie par la somme de deux gaussiennes ajustées sur l'histogramme des points germes attribués à l'objet et  $\Pr(I/\text{"fond"})$  est définie par le lissage




FIG. 2 – Distributions de probabilité  $\Pr(I/\text{"objet"})$  (à gauche) et  $\Pr(I/\text{"fond"})$  (à droite).

de l'histogramme normalisé des points germes attribués au fond (Fig. 2). Les paramètres  $\lambda = 0,15$  et  $\sigma = 5$  ont été définis de manière ad hoc.

Après cette phase d'apprentissage, la construction du graphe, l'attribution des poids initiaux aux liens et le calcul de la partition du graphe prend environ 10 à 30 secondes sur un PC bi-processeur Xeon à 1.6Ghz et 2 Go de Ram. Dans certains cas, de légers post-traitements (extraction de la plus grande région connexe, dilatation, etc.) ont été nécessaires afin d'extraire au mieux la structure visée.

Cette procédure a été effectuée itérativement afin d'extraire successivement le foie, le réseau vasculaire hépatique et la tumeur.

La figure 3 montre le foie segmenté superposé sur une coupe et en visualisation 3D. La visualisation 3D par transparence de la figure 4 permet de situer la tumeur par rapport au foie et à sa vascularisation. Les résultats présentés sur la figure 5 concernent directement notre problématique clinique et montrent le voisinage direct de la tumeur suivant différents angles de vue. Ce type de résultat, qui est un des objectifs médicaux de notre segmentation, aura un impact direct dans la définition du planning opératoire futur.




FIG. 3 – Visualisation du foie extrait par segmentation : superposé sur une coupe (à gauche) et en visualisation 3D (à droite). Ce dernier type de représentation permet de situer le volume hépatique par rapport aux côtes, à la colonne vertébrale et aux reins.

## 5 Discussion

Plusieurs éléments critiques sont à prendre en compte avec ce type d'approche :

- Le nombre de points utilisés pour l'apprentissage et, plus encore, le choix de leurs positions ont une influence directe sur le résultat. Deux phénomènes ex-




FIG. 4 – Visualisation 3D par transparence du foie, de la tumeur et des vaisseaux.




FIG. 5 – Relations de la tumeur avec les vaisseaux sanguins environnant. Vue de face (à gauche), de derrière (au centre) et de dessus (à droite).

pliquent principalement cette influence.

1. La qualité de l'estimation des distributions de probabilité. La sélection d'un trop grand nombre de points peut aplatiser les histogrammes, spécialement pour les régions hétérogènes. De ce fait, les deux histogrammes (objet et fond) doivent être construits à partir d'un nombre de points à peu près équivalents afin d'obtenir un bon équilibre entre les deux distributions de probabilités. La constante  $A$  de l'équation 5 est aussi directement liée au nombre de points sélectionnés.
2. Les points d'apprentissage sont les points germes de la segmentation. Dans le cas où deux structures différentes sont voisines, un choix judicieux de la position des points germes peut favoriser ou non la segmentation.

Ceci impose un léger entraînement de la part de l'utilisateur avant de réaliser cette tâche spécifique. Cependant le haut niveau d'interactivité et la rapidité de segmentation facilitent cette étape.

- Cette méthode inclut des paramètres comme  $\lambda$  ou  $\sigma$  qui sont assez délicats à estimer et qui peuvent dépendre des données. Ici encore, un entraînement est nécessaire afin d'estimer ces paramètres de manière ad hoc. Mais là encore, le haut niveau d'interactivité et la rapidité de segmentation facilitent ce choix.

Un certain nombre d'améliorations sont en cours pour résoudre ces points critiques.

Cependant, cette technique présente des intérêts réels. Elle est suffisamment générique pour être facilement adaptée à la plupart des besoins de segmentation que l'on peut trouver dans nombres d'applications médicales. Elle requiert un degré d'interactivité relativement faible comparé

à d'autres méthodes de segmentation manuelle ce qui représente un avantage pour l'utilisateur. Cette méthode est de surcroît assez rapide pour permettre une validation et une correction interactive itérative.

## 6 Conclusion

Une méthode de segmentation semi-automatique rapide basée sur le graph-cut a été mise en place. Elle a été utilisée pour segmenter le foie, les tumeurs, et le réseau vasculaire hépatique à partir de volumes scanner X. Cette méthode ne nécessite qu'un court apprentissage, un degré d'interactivité relativement faible et est suffisamment rapide pour être utilisée dans un contexte médicale. Dans notre cas spécifique, le traitement mini-invasif des cancers primitifs du foie par ultrasons de haute intensité, les résultats obtenus ont un impact direct sur la définition du planning thérapeutique.

## Références

- [1] H. B. El-Serag and A. C. Mason, "Rising incidence of hepatocellular carcinoma in the united states," *N Engl J Med*, vol. 340, no. 10, pp. 745–50, 1999.
- [2] E. Mor, R. T. Kasper, P. Sheiner, and M. Schwartz, "Treatment of hepatocellular carcinoma associated with cirrhosis in the era of liver transplantation," *Ann Intern Med*, vol. 129, no. 8, pp. 643–53, 1998.
- [3] R. A. Lencioni, H. P. Allgaier, D. Cioni, M. Olshewski, P. Deibert, L. Crocetti, H. Frings, J. Laubenberger, I. Zuber, H. E. Blum, and C. Bartolozzi, "Small hepatocellular carcinoma in cirrhosis : randomized comparison of radio-frequency thermal ablation versus percutaneous ethanol injection," *Radiology*, vol. 228, no. 1, pp. 235–40, 2003.
- [4] C. Lafon, J. Y. Chapelon, F. Prat, F. Gorry, Y. Theillere, and D. Cathignol, "Design and in vitro results of a high intensity ultrasound interstitial applicator," *Ultrasonics*, vol. 36, no. 1-5, pp. 683–7, 1998.
- [5] D. M. Greig, B. T. Porteous, and A. H. Seheult, "Exact maximum a posteriori estimation for binary images," *J. Roy. Statist. Soc. B*, vol. 51, no. 2, pp. 271–279, 1989.
- [6] Y. Boykov, O. Veksler, and R. Zabih, "Fast approximate energy minimization via graph cuts," *IEEE Trans Pattern Anal Mach Intell*, vol. 23, no. 11, pp. 1222–1239, 2001.
- [7] Y. Boykov and M.-P. Jolly, "Interactive graph cuts for optimal boundary & region segmentation of objects in n-d images," in *8th Int. Conf. on Comp. Vis. ICCV'01*, vol. 1, (Vancouver), pp. 105–112, 2001.
- [8] Y. Boykov and G. Funka-Lea, "Graph-cuts and efficient n-d image segmentation," *Int. J. Comp. Vis.*, vol. 70, no. 2, pp. 109–131, 2006.
- [9] A. P. Dempster, N. M. Laird, and D. B. Rubin, "Maximum likelihood from incomplete data via the EM algorithm," *J. Roy. Statist. Soc. B*, vol. 39, no. 1, pp. 1–38, 1977.